

Sistema Adaptativo Educacional Baseado na Combinação de Dimensões da Aprendizagem

Renan Grion¹, Laura O. Moraes¹

¹Universidade Federal do Estado do Rio de Janeiro (UNIRIO)
Rio de Janeiro – RJ – Brasil

renan.grion@edu.unirio.br, laura@uniriotec.br

Abstract. *Adaptive educational systems personalize learning according to students' characteristics. However, many approaches prioritize academic performance and give limited attention to other dimensions. This research investigates how cognitive, metacognitive, and affective dimensions influence the personalization of adaptive learning pathways. A fuzzy logic-based model integrates performance, perceived difficulty, and self-confidence to recommend Reinforcement, Regular, or Challenge pathways. The research comprises a literature mapping and evaluations in Arduino Robotics and Generative AI Fundamentals courses. The results indicate the feasibility and potential of the multidimensional approach to personalize learning.*

Keywords— *Adaptive Educational Systems, Fuzzy Logic, Learning Personalization.*

Resumo. *Sistemas adaptativos educacionais personalizam a aprendizagem conforme características dos estudantes. Entretanto, muitas abordagens priorizam o desempenho acadêmico e pouco exploram outras dimensões. Esta pesquisa investiga como dimensões cognitivas, metacognitivas e afetivas influenciam a personalização de trilhas adaptativas. Um modelo baseado em lógica fuzzy integra desempenho, dificuldade percebida e autoconfiança para recomendar trilhas de Reforço, Regular ou Desafio. A pesquisa compreende mapeamento da literatura e avaliações em cursos de Robótica com Arduino e Fundamentos de IA Generativa. Os resultados indicam a viabilidade e o potencial da abordagem multidimensional para personalizar a aprendizagem.*

Palavras-chave— *Sistemas Adaptativos Educacionais, Lógica Fuzzy, Personalização da Aprendizagem.*

1. Introdução

Sistemas adaptativos educacionais têm sido amplamente utilizados para personalizar conteúdos, atividades e estratégias pedagógicas de acordo com características individuais dos estudantes. Com o avanço da Inteligência Artificial (IA), esses sistemas passaram a incorporar mecanismos capazes de analisar dados educacionais para gerar recomendações personalizadas em diferentes contextos de aprendizagem [Hwang *et al.* 2020; Ezzaim *et al.* 2024].

Entretanto, estudos recentes indicam que muitas abordagens adaptativas concentram suas decisões principalmente em indicadores de desempenho acadêmico, utilizando informações cognitivas como principal fonte para personalização [Wang *et al.* 2020]. Embora relevantes, tais indicadores não contemplam integralmente fatores

relacionados à percepção de dificuldade e à autoconfiança dos estudantes, aspectos reconhecidos na literatura como importantes para o processo de aprendizagem [Flavell 1979; Panadero 2017; Ghergulescu *et al.* 2021].

Nesse contexto, esta pesquisa investiga o uso combinado de dimensões cognitivas, metacognitivas e afetivas para apoiar a personalização de trilhas em sistemas adaptativos educacionais. A proposta utiliza lógica fuzzy para integrar informações de desempenho, dificuldade percebida e autoconfiança, recomendando percursos de aprendizagem classificados em Reforço, Regular ou Desafio.

A pesquisa é orientada pela seguinte questão: *Como a combinação de dimensões cognitivas, metacognitivas e afetivas influencia a personalização de trilhas em sistemas adaptativos educacionais?*

Para responder a essa questão, foi realizado inicialmente um mapeamento sistemático da literatura sobre sistemas adaptativos baseados em IA na Educação a Distância. Em seguida, o modelo foi avaliado em um curso presencial de Robótica com Arduino e posteriormente ampliado para um curso on-line de Fundamentos de Inteligência Artificial Generativa. Atualmente, essas etapas encontram-se concluídas, e os resultados obtidos subsidiam uma nova fase da pesquisa voltada ao refinamento do mecanismo de inferência fuzzy a partir dos dados coletados durante a aplicação do sistema em ambiente on-line.

2. Fundamentação Teórica

Esta seção apresenta os conceitos que fundamentam a proposta deste estudo.

2.1. Sistemas Adaptativos na Educação

Sistemas adaptativos educacionais utilizam informações sobre o estudante para personalizar conteúdos, atividades e estratégias de aprendizagem. Com a incorporação de técnicas de Inteligência Artificial, esses sistemas passaram a utilizar diferentes mecanismos de modelagem do estudante, recomendação de recursos e análise de dados educacionais, buscando oferecer experiências mais adequadas às necessidades individuais do aluno [Hwang *et al.* 2020; Wang *et al.* 2020; Ezzaim *et al.* 2024].

O mapeamento sistemático conduzido nesta pesquisa identificou a utilização de diferentes abordagens, incluindo aprendizado de máquina, lógica fuzzy, redes Bayesianas, sistemas tutores inteligentes e modelos de linguagem de larga escala. Os estudos analisados também indicaram benefícios relacionados à personalização do ensino, aumento do engajamento e melhoria do desempenho acadêmico dos estudantes.

2.2. Dimensões da Aprendizagem

Embora muitos sistemas adaptativos utilizem predominantemente indicadores de desempenho acadêmico para orientar suas decisões, o processo de aprendizagem envolve múltiplas dimensões. Entre elas destacam-se a dimensão cognitiva, relacionada ao domínio do conteúdo; a dimensão metacognitiva, associada à capacidade de monitorar e regular a própria aprendizagem; e a dimensão afetiva, relacionada a fatores como motivação, percepção de competência e autoconfiança [Flavell 1979; Panadero 2017].

A integração dessas dimensões pode contribuir para uma representação mais abrangente do estudante, permitindo que mecanismos adaptativos considerem não apenas o que o aluno sabe, mas também como percebe suas dificuldades e sua capacidade de enfrentar novos desafios [Ghergulescu *et al.* 2021].

2.3. Lógica Fuzzy na Personalização Educacional

A lógica fuzzy tem sido utilizada em sistemas adaptativos por sua capacidade de representar incertezas e gradualidades presentes em contextos educacionais [Al Duhayyim and Newbury 2018; Ghergulescu *et al.* 2021; Szczepański and Marciniak 2023]. Diferentemente de abordagens baseadas em limiares rígidos, a inferência fuzzy permite combinar múltiplos indicadores e produzir recomendações graduais de acordo com diferentes perfis de estudantes.

Nesta pesquisa, a lógica fuzzy foi adotada para integrar evidências cognitivas, metacognitivas e afetivas, gerando um escore contínuo utilizado na recomendação de trilhas de aprendizagem classificadas em Reforço, Regular ou Desafio. Essa abordagem busca ampliar a capacidade de personalização do sistema ao considerar diferentes aspectos do processo de aprendizagem.

3. Proposta de Pesquisa

O objetivo desta pesquisa é investigar como a combinação de dimensões cognitivas, metacognitivas e afetivas influencia a personalização de trilhas em sistemas adaptativos educacionais. Para isso, foi desenvolvido um sistema adaptativo baseado em lógica fuzzy capaz de integrar diferentes evidências de aprendizagem e recomendar percursos personalizados aos estudantes.

A dimensão cognitiva é representada pelo desempenho obtido nos quizzes realizados ao longo do curso. A dimensão metacognitiva corresponde à percepção de dificuldade informada pelos participantes após cada tópico. Por sua vez, a dimensão afetiva é representada pelo nível de autoconfiança declarado pelos estudantes em relação ao conteúdo estudado.

Os dados coletados são processados por um mecanismo de inferência fuzzy responsável por combinar as três dimensões e produzir um escore adaptativo contínuo. Esse escore é utilizado para recomendar uma das três trilhas de aprendizagem disponíveis:

- **Reforço:** destinada a estudantes que necessitam de suporte adicional para consolidação dos conteúdos;
- **Regular:** destinada a estudantes que apresentam desempenho compatível com a progressão prevista do curso;
- **Desafio:** destinada a estudantes que demonstram condições de avançar para atividades complementares de maior complexidade.

A arquitetura geral do sistema é apresentada na Fig. 1. O modelo foi implementado utilizando páginas HTML e JavaScript para interação com os participantes, Google Apps Script para processamento das regras adaptativas e Google Sheets para armazenamento dos dados educacionais coletados durante a execução dos cursos.




Figura 1. Modelo adaptativo baseado em dimensões da aprendizagem.

Diferentemente de abordagens que utilizam exclusivamente indicadores de desempenho, o modelo proposto busca representar a aprendizagem de forma multidimensional, incorporando simultaneamente evidências relacionadas ao conhecimento do estudante, à sua percepção sobre o processo de aprendizagem e aos aspectos afetivos associados à realização das atividades. Essa estratégia procura ampliar a capacidade de personalização do sistema e produzir recomendações mais aderentes às necessidades individuais dos participantes.

4. Etapas da Pesquisa

A pesquisa está estruturada em três etapas complementares, com o objetivo de compreender o estado da arte dos sistemas adaptativos educacionais, desenvolver o modelo proposto e avaliá-lo em diferentes contextos de aprendizagem. A primeira etapa consiste na realização de um mapeamento sistemático da literatura sobre sistemas adaptativos baseados em Inteligência Artificial aplicados à Educação a Distância. Os resultados permitiram identificar as principais técnicas empregadas na área, bem como benefícios, desafios e lacunas de pesquisa, destacando a predominância de abordagens centradas em indicadores de desempenho acadêmico.

Na segunda etapa, foi desenvolvido e avaliado um sistema adaptativo baseado em lógica fuzzy para o ensino de Robótica com Arduino. O experimento foi conduzido em contexto presencial com estudantes do Ensino Fundamental II e teve como principal objetivo validar a integração de dimensões cognitivas, metacognitivas e afetivas no processo de recomendação de trilhas de aprendizagem.

Por fim, a terceira etapa consiste na ampliação do modelo para um curso de Fundamentos de Inteligência Artificial Generativa. Diferentemente da aplicação anterior, essa etapa foi conduzida em ambiente de Educação a Distância e permitiu avaliar o comportamento do sistema em uma amostra maior e mais heterogênea,

incluindo grupos controle e experimental. A Tabela 1 apresenta uma síntese das principais etapas da pesquisa.

Tabela 1. Caracterização das etapas da pesquisa

Etapas	Amostra	Contexto
MSL	20 estudos	Mapeamento sistemático
Exp. 1	14 estudantes	Robótica (presencial)
Exp. 2	43 participantes	IA Generativa (EaD)

Atualmente, as três etapas previstas encontram-se concluídas. Os resultados obtidos fornecem evidências iniciais sobre a viabilidade da utilização de múltiplas dimensões da aprendizagem para apoiar a personalização de trilhas em sistemas adaptativos educacionais. A próxima etapa da pesquisa consiste no refinamento do mecanismo de inferência fuzzy a partir dos dados coletados durante a aplicação do sistema em ambiente on-line, buscando aprimorar a capacidade adaptativa do modelo proposto.

5. Resultados Preliminares

Os resultados obtidos até o momento fornecem evidências iniciais sobre a utilização de múltiplas dimensões da aprendizagem para apoiar a personalização de trilhas em sistemas adaptativos educacionais.

No Experimento 1, realizado em um curso presencial de Robótica com Arduino, o modelo adaptativo demonstrou viabilidade operacional ao integrar indicadores cognitivos, metacognitivos e afetivos para recomendar automaticamente trilhas de Reforço, Regular e Desafio. Os resultados forneceram evidências iniciais sobre a aplicabilidade da abordagem proposta e motivaram sua ampliação para um contexto de Educação a Distância.

O principal conjunto de evidências foi obtido no Experimento 2, conduzido em um curso on-line de Fundamentos de Inteligência Artificial Generativa. O estudo contou com 43 participantes, distribuídos entre grupo controle ($n=23$) e grupo experimental ($n=20$). As análises comparativas indicaram que ambos os grupos apresentaram níveis equivalentes de conhecimento prévio ($p=0.867$). Embora tenham sido observadas melhorias em ambos os grupos ao final do curso, não foram identificadas diferenças estatisticamente significativas para pós-teste ($p=0.227$) ou ganho de aprendizagem ($p=0.181$).

Além dos indicadores tradicionais de desempenho, o sistema registrou continuamente informações relacionadas à percepção de dificuldade e à autoconfiança dos participantes, permitindo a construção de perfis multidimensionais de aprendizagem. Durante a execução do curso, o mecanismo adaptativo realizou 80 decisões de trilha, evidenciando o funcionamento efetivo do processo de personalização. Aproximadamente 45% das recomendações direcionaram os participantes para atividades de Desafio, 42,5% para atividades de Reforço e 12,5% para a trilha Regular, conforme apresentado na Fig. 2.




Figura 2. Distribuição das trilhas geradas pelo sistema adaptativo.

Um resultado particularmente relevante foi obtido por meio da análise preditiva das dimensões da aprendizagem. Modelos de regressão múltipla foram construídos utilizando variáveis cognitivas, metacognitivas e afetivas coletadas ao longo dos quatro tópicos do curso. Os modelos apresentaram alto poder explicativo (R^2 entre 0.80 e 0.82), indicando que as informações coletadas durante a interação dos participantes com o ambiente foram capazes de explicar parcela substancial da variabilidade observada no desempenho final.

Os resultados indicaram que variáveis associadas ao desempenho acadêmico, à percepção de dificuldade e à autoconfiança contribuíram simultaneamente para explicar os resultados de aprendizagem. Destacaram-se a nota obtida no Tópico 03 ($\beta = 0.059$, $p = 0.002$), a dificuldade percebida no Tópico 03 ($\beta = 0.899$, $p = 0.027$), a autoconfiança no Tópico 02 ($\beta = -0.952$, $p = 0.027$) e a autoconfiança no Tópico 03 ($\beta = 1.093$, $p = 0.036$). Em contraste, a nota do pré-teste apresentou baixa contribuição explicativa, sugerindo que as experiências vivenciadas ao longo do curso forneceram maior capacidade preditiva do desempenho final do que o conhecimento prévio dos participantes.

De forma geral, os resultados obtidos fornecem evidências favoráveis à utilização de modelos multidimensionais para apoiar mecanismos de personalização em sistemas adaptativos educacionais. A relevância simultânea de variáveis cognitivas, metacognitivas e afetivas reforça a hipótese central desta pesquisa e fornece subsídios para a próxima etapa do trabalho, que consiste no refinamento do mecanismo de inferência fuzzy a partir dos padrões identificados durante a aplicação do sistema em ambiente on-line.

6. Próximas Etapas da Pesquisa

Embora os resultados obtidos até o momento demonstrem a viabilidade do modelo adaptativo proposto, a pesquisa ainda se encontra em evolução. As evidências observadas nos experimentos realizados indicam oportunidades para aprimorar o mecanismo de personalização e aprofundar a compreensão da influência das diferentes dimensões da aprendizagem no desempenho dos estudantes.

Os resultados da análise preditiva mostraram que variáveis cognitivas, metacognitivas e afetivas contribuíram simultaneamente para explicar o desempenho final dos participantes, enquanto o conhecimento prévio apresentou baixa capacidade explicativa. Esses achados sugerem que as funções de pertinência e as regras atualmente utilizadas pelo sistema podem ser refinadas a partir dos padrões observados nos dados empíricos coletados durante a aplicação do curso.

Nesse contexto, a próxima etapa da pesquisa consiste na realização de um novo ciclo experimental, denominado Experimento 2.2. Essa etapa terá como objetivo recalibrar o mecanismo de inferência fuzzy utilizando os resultados obtidos no Experimento 2, buscando aprimorar a sensibilidade do sistema às diferentes características dos estudantes e melhorar a qualidade das recomendações de trilha.

Além do refinamento das funções de pertinência, pretende-se revisar as regras de inferência fuzzy atualmente utilizadas, incorporando evidências derivadas das análises estatísticas e preditivas realizadas. Espera-se que essa abordagem permita produzir recomendações mais aderentes aos perfis observados durante a aprendizagem e ampliar a capacidade de personalização do sistema.

Por fim, pretende-se ampliar a amostra de participantes e realizar novas avaliações em contextos de Educação a Distância, investigando não apenas indicadores de desempenho, mas também aspectos relacionados ao engajamento, à autorregulação da aprendizagem e à experiência do usuário. Dessa forma, espera-se obter evidências adicionais sobre o papel da combinação de dimensões cognitivas, metacognitivas e afetivas na personalização de trilhas em sistemas adaptativos educacionais.

7. Considerações Finais

Este trabalho apresentou o estágio atual de uma pesquisa de mestrado que investiga a influência da combinação de dimensões cognitivas, metacognitivas e afetivas na personalização de trilhas em sistemas adaptativos educacionais. Para isso, foi proposto um modelo adaptativo baseado em lógica fuzzy capaz de integrar diferentes evidências da aprendizagem para recomendar percursos de Reforço, Regular ou Desafio.

A pesquisa está estruturada em três etapas complementares. Inicialmente, um mapeamento sistemático da literatura permitiu identificar tendências e lacunas relacionadas ao uso de Inteligência Artificial em sistemas adaptativos educacionais. Em seguida, o modelo foi avaliado em um curso presencial de Robótica com Arduino e posteriormente ampliado para um curso on-line de Fundamentos de Inteligência Artificial Generativa, possibilitando sua análise em contexto de Educação a Distância.

Os resultados obtidos até o momento indicam que variáveis cognitivas, metacognitivas e afetivas apresentam potencial para explicar parte das diferenças observadas no desempenho dos estudantes, reforçando a relevância de abordagens multidimensionais para modelagem do aprendiz. Além disso, os resultados da análise preditiva sugerem que informações coletadas ao longo do processo de aprendizagem possuem maior capacidade explicativa do desempenho final do que medidas isoladas de conhecimento prévio.

Como continuidade da pesquisa, pretende-se refinar o mecanismo de inferência fuzzy a partir das evidências empíricas obtidas nos experimentos realizados, bem como ampliar a avaliação do modelo em novos contextos educacionais. Espera-se que os

resultados contribuam para o avanço do conhecimento sobre personalização da aprendizagem e para o desenvolvimento de sistemas adaptativos mais sensíveis às diferentes características dos estudantes.

Em conformidade com os princípios da Ciência Aberta, os scripts e notebooks utilizados nas análises estatísticas, bem como os códigos necessários para a reprodução do curso adaptativo, estão disponíveis publicamente em: <https://doi.org/10.5281/zenodo.20578338>.

Referências

- Al Duhayyim, M. and Newbury, P. (2018). “Concept-based and Fuzzy Adaptive E-learning”. In *Proceedings of the 3rd International Conference on Information and Education Innovations (ICIEI 2018)*, pp. 49–56. ACM. <https://doi.org/10.1145/3234825.3234832>.
- Ezzaim, A., Dahbi, A., Haidine, A., Aqqal, A. (2024). “Development, Implementation, and Evaluation of a Machine Learning-Based Multi-Factor Adaptive E-Learning System”. *IAENG International Journal of Computer Science*, 51(9), 1250–1271.
- Flavell, J. H. (1979). “Metacognition and cognitive monitoring: A new area of cognitive-developmental inquiry”. *American Psychologist*, 34(10), 906–911. <https://doi.org/10.1037/0003-066X.34.10.906>.
- Ghergulescu, I., Flynn, C., O'Sullivan, C., van Heck, I. and Slob, M. (2021). “A Conceptual Framework for Extending Domain Model of AI-enabled Adaptive Learning with Sub-skills Modelling”. In: *Proceedings of the 13th International Conference on Computer Supported Education (CSEDU 2021)*, vol. 1, pp. 116–123. <https://doi.org/10.5220/0010451201160123>.
- Hwang, G.-J., Sung, H.-Y., Chang, S.-C., and Huang, X.-C. (2020). “A fuzzy expert system-based adaptive learning approach to improving students’ learning performances by considering affective and cognitive factors”. *Computers and Education: Artificial Intelligence*, 1, 100003. <https://doi.org/10.1016/j.caeai.2020.100003>.
- Panadero, E. (2017). “A review of self-regulated learning: Six models and four directions for research”. *Frontiers in Psychology*, 8, 422. <https://doi.org/10.3389/fpsyg.2017.00422>.
- Szczepański, M. and Marciniak, J. (2023). “Application of a Fuzzy Controller in Adaptive E-Learning Content Used to Evaluate Student Activity”. *Procedia Computer Science*, 225, 2526–2535. <https://doi.org/10.1016/j.procs.2023.10.244>.
- Wang, S., Christensen, C., McBride, E. A., Kelly, H., Cui, W., Tong, R., Shear, L., Yarnall, L. and Feng, M. (2020). “Identifying Gaps in Use of and Research on Adaptive Learning Systems”. In: *International Conference on Computer Supported Education*, pp. 118-124. <https://doi.org/10.5220/0009590701180124>.